

SVEUČILIŠTE U ZAGREBU  
RUDARSKO – GEOLOŠKO – NAFTNI FAKULTET

Diplomski studij rudarstva

**PREDIKTIVNI MODEL NASTANKA KOMUNALNOG OTPADA U HRVATSKOJ  
NA TEMELJU PODATAKA O OTPADU U RAZDOBLJU 2009. - 2017.**

Diplomski rad

Ivan Krivić

R198

Zagreb, 2019.

PREDIKTIVNI MODEL NASTANKA KOMUNALNOG OTPADA U HRVATSKOJ NA  
TEMELJU PODATAKA O OTPADU U RAZDOBLJU 2009. - 2017.

IVAN KRIVIĆ

Diplomski rad izrađen: Sveučilište u Zagrebu

Rudarsko-geološko-naftni fakultet

Zavod za mineralogiju, petrologiju i mineralne sirovine

Pierottijeva 6, 10000 Zagreb

Sažetak

Otpad, te posljedice lošeg gospodarenja otpadom kao što su onečišćavanje tla, zraka i mora neki su od glavnih problema današnjice. Europsko gospodarstvo još uvijek gubi značajnu količinu potencijalnih sekundarnih sirovina iz otpada. Za kvalitetno planiranje i upravljanje u gospodarenju otpadom te rješavanje tih problema u kontekstu ekonomskih i demografskih promjena nužno je moći predvidjeti trendove proizvodnje otpada. U ovom radu se istražuju prediktivne metode prognoziranja proizvodnje komunalnog otpada za RH na temelju podataka iz razdoblja 2009.-2017. Izrađeni su različiti regresijski modeli za predviđanje proizvedene količine komunalnog otpada u RH na temelju tri nezavisne varijable: broj stanovnika, turistički ekvivalent stanovnika i ukupna godišnja neto plaća zaposlenih u pravnim osobama. Najbolje rezultate pokazali su regresijski modeli populacijskih i ekonomskih pokazatelja.

Ključne riječi: komunalni otpad, nastanak otpada, gospodarenje otpadom, prediktivni model

Diplomski rad sadrži: 33 stranice, 3 tablice, 10 slika, 3 priloga i 40 referenci

Jezik izvornika: hrvatski

Diplomski rad pohranjen: Knjižnica Rudarsko-geološko-naftnog fakulteta, Pierottijeva 6, Zagreb

Mentor: Dr. sc. Anamarija Grbeš, docentica RGNF

Ocjenjivači: Dr. sc. Anamarija Grbeš, docentica RGNF

Dr. sc. Želimir Veinović, docent RGNF

Dr. sc. Rajna Rajić, redoviti profesor RGNF

Datum obrane: 15. veljače 2019, Rudarsko-geološko-naftni fakultet Sveučilišta u Zagrebu

PREDICTIVE MODEL OF MUNICIPAL WASTE GENERATION IN CROATIA BASED ON  
DATA ON WASTE IN THE PERIOD 2009. - 2017.

IVAN KRIVIĆ

Thesis completed in: University of Zagreb  
Faculty of Mining, Geology and Petroleum engineering  
Institute of Mineralogy, Petrology and Mineral deposits,  
Pierottijeva 6, 10 000 Zagreb

Abstract

Waste and consequences of inefficient waste management such as pollution of soil, air, water and ocean are some of the main issues in modern world. European economies are still losing significant quantities of secondary resources in waste. Solution of those problems requires constant improvement and control of waste management systems, and resilience to changes. Planning for the more efficient waste management and circular economy in context of economic and demographic changes, requires ability to predict the waste generation depending on the level of changes in the observed society. This research foccuses on predictive modelling of municipal waste generation in Croatia, based on data for period 2009-2017, and presents different regression predictive models: based on population, tourist equivalent of the population, and based on total anual net wages of employed in legal enterprises. Regression models of population and economy variables have resulted in the best prediction of municipal solid waste.

Keywords: municipal solid waste, waste generation, waste management, predictive modelling

Thesis contains: 33 pages, 3 tables, 10 figures, 3 appendixes and 40 references

Original in: Croatian

Thesis deposited in: Library of Faculty of Mining, Geology and Petroleum Engineering,  
Pierottijeva 6, Zagreb

Supervisor: Assistant professor Anamarija Grbeš, PhD

Reviewers: Assistant professor Anamarija Grbeš, PhD

Assistant professor Želimir Veinović, PhD

Full professor Rajna Rajić, PhD

Defence date: February 15, 2019, Faculty of Mining, Geology and Petroleum Engineering,  
University of Zagreb

## SADRŽAJ

POPIS TABLICA.....	II
POPIS SLIKA.....	III
POPIS PRILOGA.....	IV
1. UVOD.....	1
2. PREGLED DOSADAŠNJIH ISTRAŽIVANJA .....	4
2.1. Gospodarenje komunalnim otpadom u Hrvatskoj .....	4
2.2. Uloga lokalne zajednice u gospodarenju komunalnim otpadom .....	5
2.3. Znanstvena istraživanja proizvodnje i upravljanja otpadom u Hrvatskoj.....	6
2.4. Modeli nastanka otpada .....	7
3. MATERIJALI I METODE.....	9
3.1. Ulazni podaci i izvori.....	9
3.2. Deskriptivna statistika.....	10
3.3. Metoda linearne regresije.....	12
3.3.1. Jednostavna linearna regresija .....	12
3.3.2. Višestruka linearna regresija .....	12
3.4. Hipoteze modela proizvodnje komunalnog otpada u Hrvatskoj u razdoblju 2009. – 2017. ....	13
3.4.1. Hipoteze modela proizvodnje komunalnog otpada na temelju vremenskog trenda	13
3.4.2. Hipoteze modela proizvođača komunalnog otpada.....	14
3.4.3. Hipoteze ekonomskog modela nastanka otpada.....	14
3.5. Metodologija proračuna modela .....	15
4. REZULTATI .....	17
4.1. Kretanja različitih društvenih i ekonomskih pokazatelja u periodu 2009. - 2017.	17
4.2. Rezultati modela proizvodnje komunalnog otpada na temelju vremenskog trenda	21
4.3. Rezultati modela proizvođača komunalnog otpada $f(x_1, x_2)$ .....	22

4.4.	Rezultati ekonomskog modela $f(x_3)$ .....	22
4.5.	Ostali rezultati regresijskih modela .....	23
5.	DISKUSIJA REZULTATA .....	24
5.1.	Promjene u sustavu gospodarenja otpadom .....	24
5.2.	Kretanje populacije koja proizvodi komunalni otpad .....	25
5.3.	Modeli proizvodnje komunalnog otpada .....	27
6.	ZAKLJUČAK .....	29
	LITERATURA .....	30
	PRILOZI .....	

## POPIS TABLICA

Tablica 3-1. Ulazni podaci za statističke proračune .....	15
Tablica 3-2. Shema proračuna za (višestruku) linearnu regresiju u programu <i>Statistica</i> ....	16
Tablica 4-1. Sumarni prikaz rezultata statističkih proračuna ( $y$ - proizvodnja komunalnog otpada ( $t$ ), $x_1$ - broj stanovnika, $x_2$ - turisti kao dodatno stanovništvo, $x_3$ - ukupna godišnja neto plaća (HRK)) .....	23

## POPIS SLIKA

Slika 1-1. Hijerarhija prioriteta u gospodarenju otpadom (Sobota, 2017) .....	2
Slika 4-1. Kretanje količine proizvedenog komunalnog otpada u RH od 2009. do 2017... ..	17
Slika 4-2. Kretanje broja stanovništva obuhvaćenog sakupljanjem otpada u RH od 2009. do 2017. ....	18
Slika 4-3. Kretanje prosječne mjesečne neto plaće u RH od 2009. do 2017.....	18
Slika 4-4. Kretanje broja noćenja turista u RH od 2009. do 2017.....	19
Slika 4-5. Kretanje godišnje neto plaće u RH od 2009 do 2017. ....	20
Slika 4-6. Kretanje broja stanovništva uvećanog za ekvivalentni broj turista u RH od 2009. do 2017. ....	20
Slika 4-7. Kretanje broja zaposlenih u pravnim osobama u RH od 2009. do 2017. ....	21
Slika 5-1. Broj stanovnika RH i stanovništvo obuhvaćeno sakupljanjem komunalnog otpada .....	26
Slika 5-2. Turistički ekvivalent stanovništva prema dva različita načina proračuna .....	26

## **POPIS PRILOGA**

Prilog 1. Tablica društvenih i ekonomskih pokazatelja 2009. - 2017.

Prilog 2. Proračuni modela u *Statistici*

Prilog 3. Proračuni koeficijenata varijacije regresije




## 1. UVOD

Otpad, njegovo odlaganje, zbrinjavanje, recikliranje i uporaba, te posljedice lošeg gospodarenja otpadom kao što su onečišćavanje tla, zraka i mora neki su od glavnih problema današnjice. Sve više ljudi toga postaje svjesno, a važni doprinosi svijesti o važnosti otpada i rješavanju, uz njega vezanih problema, posljedica su fokusiranog rada različitih međunarodnih organizacija kroz dugi niz godina. Ujedinjeni narodi (United Nations, UN) postavili su u devetom mjesecu 2000. godine osam milenijskih razvojnih ciljeva od kojih jedan glasi: „osigurati održivost okoliša“ (Rudan i dr., 2017). Napravljene su velike stvari po pitanju održivosti okoliša s tvarima koje oštećuju ozonski omotač koje su praktički eliminirane (Rudan i dr., 2017). Više od 90% svjetske populacije dobiva pristup poboljšanoj vodi a postotak urbanog stanovništva koji živi u predgrađu smanjen je s 40 na 30%. Nakon značajnih rezultata, 2015. godine osam milenijskih razvojnih ciljeva prošireno je na sedamnaest ciljeva održivog razvoja koji su još širi i otvoreniji (Rudan i dr., 2017). Održivi razvoj uključuje sve izvorne milenijske razvojne ciljeve, ali i dodatne ciljeve koji su postali sve važniji za zajednice u svim područjima svijeta i relevantni za život u 21. stoljeću (Rudan i dr., 2017). Održivi razvoj prvi put je definiran 1987. godini u izvješću Svjetske komisije za okoliš i razvoj (WCED), tzv. Brundtland komisije, koju su UN formirali 4 godine ranije. U tom izvješću (Brundtland izvješće ili Naša zajednička budućnost) upozorava se ljude da moraju bitno promijeniti način življenja i rada, te se ističe potreba za: *„oblikom održivog razvoja koji će udovoljiti potrebama sadašnjih generacija bez da ugrožava mogućnost budućih generacija da zadovolje vlastite potrebe“* (United Nations, 1987). Uloge tih velikih i krovnih organizacija poput UN-a i Europske Unije pa čak i Svjetske zdravstvene organizacije (World Health Organization, WHO) te dobrotvornih zaklada od presudne su važnosti. Njihovi su oblici djelovanja vrlo komplicirani i često ih nije lako razumjeti, a postoji i velika potreba za njihovom koordinacijom. Bez strateškog, planskog i programskog djelovanja nema konstantnog i globalnog napretka.

Sve je jasnije da se europski model ekonomskog razvoja koji se temelji na visokoj potrošnji resursa, proizvodnji otpada i zagađenju ne može održati na dulji rok. Danas je Europska unija u velikoj mjeri ovisna o uvozu i potrebna nam je dvostruko veća površina EU kako bi se zadovoljile naše potrebe za resursima. U Europi trenutno koristimo 16 tona materijala po osobi godišnje, od čega 6 tona postaje otpad. Iako se upravljanje tim otpadom

nastavlja poboljšavati, europsko gospodarstvo još uvijek gubi značajnu količinu potencijalnih 'sekundarnih sirovina', kao što su metali, drvo, staklo, papir, plastika. U 2010. godini ukupna proizvodnja otpada u EU iznosila je 2,5 milijardi tona. Od toga je samo 36% otpada reciklirano, a ostatak je bio odložen ili spaljen, od čega se oko 600 milijuna tona moglo reciklirati ili ponovno upotrijebiti (European Commission - Environment, 2018). Ukupne količine proizvedenog komunalnog otpada u RH kreću se između 1,6 i 1,7 milijuna tona. Sukladno članku 55. ZOGO koji prenosi odredbe Okvirne direktive o otpadu, RH je obvezna do 1. siječnja 2020. putem nadležnih tijela osigurati pripremu za ponovnu uporabu i recikliranje sljedećih otpadnih materijala: papir, metal, plastika i staklo iz kućanstva, a po mogućnosti i iz drugih izvora ako su ti tokovi otpada slični otpadu iz kućanstva, u minimalnom udjelu od 50% mase otpada. Stopa recikliranja za 2017. godinu iznosila je 24% (Hrvatska agencija za okoliš i prirodu, 2018). Pretvaranje otpada u resurs je ključ za kružno gospodarstvo.

Ciljevi postavljeni u europskom zakonodavstvu su ključni pokretači za poboljšano gospodarenje otpadom. Potiču inovacije u recikliranju, ograničavaju korištenje odlagališta i stvaraju poticaje za promjenu ponašanja potrošača. Poboljšano gospodarenje otpadom također pomaže smanjiti zdravstvene i ekološke probleme, smanjiti emisije stakleničkih plinova (izravno smanjivanjem emisija iz odlagališta i neizravno recikliranjem materijala koji bi inače bili izvađeni i prerađeni), te izbjeći negativne utjecaje na lokalnoj razini kao što je narušavanje krajobraza zbog odlaganja, lokalno zagađenje voda i zraka, kao i bacanje otpada u okoliš (EU Commission - Environment, 2018).



Slika 1-1. Hijerarhija prioriteta u gospodarenju otpadom (Sobota, 2017)

Pristup Europske unije upravljanju otpadom temelji se na "hijerarhiji otpada" koja postavlja sljedeće prioritete u oblikovanju politike otpada i upravljanja otpadom na operativnoj razini: sprječavanje nastanka otpada, priprema za ponovnu uporabu, recikliranje, uporaba i kao najmanje poželjna, mogućnost odlaganja, što uključuje odlaganje ili spaljivanje bez uporabe energije (European Parliament and Council, 2012). Na slici 1-1. nalazi se slikovit prikaz prioriteta počevši od vrha piramide s najpoželjnijom prema najmanje poželjnoj opciji.

Cilj ovog istraživanja je predvidjeti proizvodnju komunalnog otpada u Hrvatskoj jer o njoj ovisi strateško planiranje i upravljanje komunalnim otpadom. U praksi, zbog nesigurnosti u točnost i nedostupnosti podataka o trenutnim i budućim količinama, potrebne su metode modeliranja za predviđanje stvaranja komunalnog otpada. Predviđanje se obično temelji na modelima koji se fokusiraju na masu i sastav otpada. Prediktivno modeliranje može uključivati bilo koju metodu modeliranja koja izražava uzrok i posljedicu, kao što su korelacijska i regresijska analiza, analiza vremenskih serija, usporedba grupa ili metode koje uključuju složenu interakciju varijabli (multivarijantna analiza, analiza ulaznog izlaza, dinamika sustava, sustavi umjetne inteligencije). U pregledima Beigla i dr. (2008) i Kolekara i dr. (2016) objavljeno je više metoda. Pronašli su brojne neovisne varijable koje se koriste u raznim studijama modeliranja koje su povezane s proizvodnjom, potrošnjom i odlaganjem. Neke od korištenih varijabli bile su populacija, dohodak ili BDP, obrazovanje, migranti, sezonske varijacije, ukupni izdaci za potrošnju, općinski porez po glavi stanovnika, zaposlenost, urbanizacija, potrošnja plina, vode i električne energije, temperatura i količina padalina, broj članova kućanstva, potrošačke navike kućanstva, trgovačka poduzeća (Grbeš i dr., neobjavljen rad). Ovo istraživanje također za cilj ima identificirati varijable koje su povezane sa stvaranjem otpada u Hrvatskoj. Podaci za istraživanje temelje se na devetogodišnjem razdoblju (2009.-2017.) i uključuju niz statističkih parametara.

## **2. PREGLED DOSADAŠNJIH ISTRAŽIVANJA**

### **2.1. Gospodarenje komunalnim otpadom u Hrvatskoj**

U Republici Hrvatskoj strateško planiranje i gospodarenje otpadom regulirano je Strategijom gospodarenja otpadom Republike Hrvatske (NN 130/2005), Zakonom o održivom gospodarenju otpadom (NN 94/2013) i podzakonskim aktima kao što su Pravilnik o gospodarenju otpadom (NN 117/2017), Pravilnik o katalogu otpada (NN 90/2015), Pravilnik o građevnom otpadu i otpadu koji sadrži azbest (NN 69/2016).

Za strateško planiranje i provođenje politika o otpadu nadležni su Vlada RH i posebno Ministarstvo zaštite okoliša i energetike. Prikupljanjem podataka, obradom i izvješćivanjem bavi se Hrvatska agencija za zaštitu okoliša i prirode.

U Hrvatskoj je 2000. postojalo 120 "službenih odlagališta", koja su zauzimala površinu od oko 450 hektara i na kojima je odloženo približno 21,000.000 tona komunalnog i njemu sličnog otpada. Samo nekoliko zadovoljavalo je sve zakonske propise Hrvatske te se koristilo u skladu s njima i imalo sve potrebne dozvole (građevnu, uporabnu, vodopravnu). Za većinu ostalih "službenih odlagališta" postojale su namjere, ili su bili u tijeku postupci njihova postupnog uređivanja i pretvaranja u sanitarna odlagališta, odnosno priprema za njihova zatvaranja i otvaranja novih lokacija (Pletikapić i dr., 2000). Od 2005. do 2017. godine ukupno je bilo evidentirano i pratilo se 316 lokacija službenih odlagališta, od čega se na 305 lokacija odlagao komunalni otpad (HAOP, 2018). Prema najnovijem izvješću o komunalnom otpadu za 2017. godinu HAOP-a, komunalni otpad se odlagao na 119 odlagališta, od čega su tri odlagališta zatvorena krajem 2017.. Dodatno se na jednom odlagalištu odlagao komunalni otpad iako je temeljem službenih podataka zatvoreno i sanacija u pripremi. Od 119 odlagališta koja su sukladno službenim podacima bila aktivna tijekom 2017. godine sanacija je završila na 32 lokacije, u tijeku je bila na 43 lokacije, a za 44 lokacije sanacija je bila u pripremi. Od ukupnog broja zatvorenih odlagališta na koja se odlagao komunalni otpad kojih je na kraju godine bilo 186, sanacija je završila na 131 lokaciji, u tijeku je bila na sedam lokacija, a u pripremi za 48 lokacija. Na 83 lokacije zatvorenih odlagališta više nema otpada. Sanacija je provedena metodom premještanja otpada - ex-situ (HAOP, 2018).

## **2.2. Uloga lokalne zajednice u gospodarenju komunalnim otpadom**

Kada se govori o ulozi lokalne zajednice u rješavanju problema otpada u Hrvatskoj, Mustapić primjećuje raširenost NIMBY<sup>1</sup> sindroma. Stoga je, uz strožu provedbu zakona prijedno potrebna intenzivna edukacija i poticanje društvenih akcija radi aktivnijega odnosa građana, prije svega po organizacijama civilnoga društva, prema ekološkim problemima, što će između ostalog postupno oslabiti očitu rasprostranjenost sindroma NIMBY (Mustapić, 2010).

Kako u svakoj regiji, županiji ili otoku odnos stanovnika prema otpadu može biti drugačiji, pokazalo je istraživanje među stanovnicima otoka Krka koje su proveli Stanić i dr. (2009). Izbjegavanje stvaranja otpada u svim promatranim aspektima pokazalo se ovisnim od varijable imovinskog statusa članova kućanstva pri čemu se uočava da je općeniti trend da s porastom prihoda raste praksa izbjegavanja stvaranja otpada, što je u suprotnosti s rezultatima nekih drugih istraživanja (Stanić i dr., 2009). To se donekle može potkrijepiti podatkom da je varijabla podržavanje uvođenja viših cijena komunalija te sudjelovanje u akcijama čišćenja i reciklaže imala veću podršku obrazovanijeg stanovništva otoka Krka, odnosno da imaju izraženiju ekološku svijest i volju. (Damjanić, 2013).

U Republici Hrvatskoj komunalni otpad, osim što predstavlja obavezu lokalnoj samoupravi, predstavlja i gospodarski potencijal. Njegovo sakupljanje i zbrinjavanje trebalo bi optimizirati, a u skladu s mogućnostima, organizirati i provoditi na način kojim se maksimizira gospodarska korist, a minimizira utjecaj na okoliš i resurse. Jedan od preduvjeta za uspješno rješavanje takvog složenog zadatka je postojanje analiza i pokazatelja temeljenih na znanstvenom pristupu. U radu kolegice (Ljubić, 2015) obrađeni su podaci iz sustava prikupljanja komunalnog otpada (količina otpada i količina utrošenog goriva) u Republici Hrvatskoj za 2013. godinu. Podaci su prikupljeni u Agenciji za zaštitu okoliša te direktnim kontaktom s tvrtkama sakupljačima otpada u svim županijama. Analizirani su u odnosu na broj stanovnika, dužinu prometnica, broj noćenja, površine županija, korišteno poljoprivredno zemljište, broj kućanstava, prosječne neto plaće i broj zaposlenih u pojedinim županijama i u čitavoj državi. Krajnji zaključci rada su: „Na količinu sakupljenog otpada najveći utjecaj imaju broj noćenja turista, korišteno poljoprivredno zemljište, broj zaposlenih te ukupne plaće. Na potrošnju dizelskog goriva,

---

<sup>1</sup> Not In My Back Yard ili „ne u mom dvorištu“

od analiziranih varijabli najveći utjecaj imaju količina komunalnog otpada, površina županije, duljina prometnica te prometna razvedenost županije“ (Ljubić, 2015).

### **2.3. Znanstvena istraživanja proizvodnje i upravljanja otpadom u Hrvatskoj**

Sustav prikupljanja otpada složen je i promjenjiv proces te se stalno treba ažurirati. Studija „Integralni pristup upravljanju sustavom prikupljanja komunalnog otpada“ autora Erdelez i dr. (2007) analizira složenost i poteškoće pravilnog odabira kriterija za vrednovanje istog sustava koji za cilj ima optimizirati gospodarenje otpadom. Rad predstavlja novi integralni pristup u optimizaciji sustava prikupljanja otpada istodobnom analizom problema na tri razine optimizacije: operativnoj, taktičkoj i strateškoj. Područje istraživanje bio je otok Brač. Rezultati na operativnoj i taktičkoj razini optimizacije dali su jasne informacije vezane uz prijevoz otpada, čime se obogatila baza znanja o problemu, a upravo su kreiranje baze podataka te uključivanje GIS-a i višekriterijskih metoda odlučivanja neizostavni čimbenici pri donošenju strateških odluka (Erdelez i dr., 2007).

U radu „Odabir varijabli za stvaranje modela obradbe krutoga otpada u gradovima i naseljima Hrvatske“ (Grbeš, 2017), gdje se istražuje mehanizam nastanka otpada, prikazuju se međusobne korelacije šesnaest varijabli te se raspravlja o prirodi tih odnosa u kontekstu kauzalnosti, odnosno nezavisnosti. Koriste se deskriptivni i prediktivni modeli. Dok se deskriptivni modeli temelje na tokovima otpada (materijala) tijekom različitih faza životnoga ciklusa proizvoda prema proizvođaču otpada i od njega, prediktivni (predviđajući) modeli temelje se na faktorima koji opisuju proces nastanka otpada (Beigl i dr., 2008). Faktori u prediktivnim modelima mogu biti vodoravni – opisuju međusobnu razmjenu između različitih vrsta otpada, i okomiti – opisuju promjene u ukupnoj količini otpada nastale kao posljedica demografskoga, ekonomskoga, tehničkoga i društvenoga napretka. Modele proizvodnje otpada obilježavaju jedinica uzorkovanja, tok odnosno vrsta otpada, nezavisne varijable te metoda modeliranja (Beigl i dr., 2008). Jedinica uzorkovanja obično se temelji na administrativnim jedinicama. Kao metode modeliranja spominju se: uspoređivanje grupa, analiza (višestruke) regresije, analiza ulaza i izlaza, analiza vremenske crte i modeliranje dinamike sustava (Beigl i dr., 2008). Najvažniji zaključci studije koje je provela Grbeš (2017) su: Duljina cesta u županiji dobro korelira s ostalim parametrima u grupi koji opisuju županiju. Svakodnevna potrošnja ovisi o količini raspoloživoga novca za potrošnju – što je više novca slobodno za potrošnju, to je više

potrošačkoga odnosno komunalnoga otpada. Ako su u mogućnosti proizvesti vlastitu hranu te razgraditi ili kompostirati otpad ili njime nahraniti životinje, potrošači kojima je to način života, kao što su to stanovnici sela i predgrađa, te stanovnici područja s nižom zaposlenošću i nižim plaćama slabije koreliraju s količinom proizvedenoga komunalnog otpada, odnosno proizvode manje otpada po stanovniku negoli stanovnici gradova, gdje je veća zaposlenost i prosječno primanje. Broj turističkih noćenja koje se u kontekstu stvaranja komunalnog otpada može promatrati kao dodatno stanovništvo korelira s mnogim drugim varijablama, ali smatra se da su te korelacije posredne, a ne zavisne. Od gospodarskih pokazatelja mogu se koristiti ili ukupne netoplaće ili broj zaposlenih i prosječne netoplaće po stanovniku. Ovi pokazatelji ne uključuju ostale izvore prihoda, pa je potrebno pronaći bolji način da se prikaže količina novca za potrošnju po stanovniku. Tako strukturirane varijable mogu se smatrati nezavisnima za daljnje modeliranje nastanka komunalnoga otpada. Potrebno je ispitati kako se podaci ponašaju kada se Grad Zagreb kao posebna administrativna jedinica, radi bolje homogenosti uzoraka statistički razmatra kao dio administrativne jedinice Zagrebačka županija (Grbeš, 2017).

#### **2.4. Modeli nastanka otpada**

Kolekar i dr. (2016) u svojim su istraživanjima koristili korelacijske i regresijske modele koji se najčešće temelje na demografskim i socioekonomskim čimbenicima. Nezavisne varijable razmatrane su u većini prediktivnih modela. Međutim, sivi fuzzy dinamički model koji su razvili Chen i Chang (2000), nije se temeljio na bilo kojoj nezavisnoj varijabli (osim podataka vremenskih serija s najmanje tri vrijednosti). Neki su modeli koristili dvosmjernu analizu (samo jedna nezavisna varijabla) čija potvrda ovisi o stvarnim podacima komunalnog otpada kao što su korelacijska i regresijska analiza, analiza vremenskih serija i usporedba grupa. Ovi modeli imaju samo uzrok i posljedicu. Drugi modeli koristili su multivarijantnu analizu (više nezavisnih varijabli) kao što su analiza ulaznih izlaznih podataka, dinamika sustava, umjetni inteligentni sustav (neizrazita logika, umjetna neuronska mreža, genetski algoritmi) i metode višestruke regresije. Ove metode modeliranja stvaraju komplikacije zbog različitih interakcija s varijablama. Kao rezultat, potvrda modela postaje teška. Neki od modela koji su se općenito koristili za predviđanje proizvodnje komunalnog otpada u razdoblju od 2006. do 2014. godine su: višestruka regresijska analiza (Shan 2010; Dai i dr., 2011; Keser i dr., 2012), neizrazita logika (Oumarou i dr., 2012), geografski informacijski sustav (Keser i dr., 2012), jednostruka

regresijska analiza (Thanh i dr., 2010; Lebersorger i Beigl, 2011) itd. Pregled modela predviđanja stvaranja krutog otpada pokazao je da su ukupna veličina kućanstva, razina dohotka kućanstava i razina obrazovanja najčešći atributi koji utječu na stvaranje otpada. Glavna ograničenja u predviđanju stvaranja komunalnog krutog otpada su svakako nedostatak službenih podataka o atributima koji utječu na stvaranje komunalnog otpada, posebno u zemljama u razvoju te činjenica da se predviđanje temeljeno na varijablama jednog uzorka ne mora nužno podudarati s predviđanjem temeljenim na istim varijablama drugog uzorka obzirom da razina povezanosti između tih varijabla nije uvijek ista (Kolekar i dr., 2016).



### **3. MATERIJALI I METODE**

U ovom poglavlju opisuju se ulazni podaci i njihovi izvori, metode obrade i analize podataka. Nakon toga opisuju se postavljeni modeli, hipoteze te koraci u postupku proračuna parametara postavljenih modela i načina njihove verifikacije.

#### **3.1. Ulazni podaci i izvori**

U ovom radu, a na temelju prethodnih istraživanja (Ljubić 2015, Grbeš i dr., 2016, Grbeš 2017) razmatrani su sljedeći tipovi podataka odnosno varijabli:

1. Ukupan broj stanovnika, procijenjeni broj stanovnika prema Državnom zavodu za statistiku Republike Hrvatske
2. Korigirani broj stanovnika obuhvaćen sakupljanjem komunalnog otpada
3. Prosječna mjesečna neto plaća, ukupna godišnja neto plaća
4. Broj zaposlenih
5. Specifična masa otpada po kuni iz neto godišnje plaće
6. Broj noćenja turista
7. Količina komunalnog otpada iz turizma
8. Količina proizvedenog otpada po turistu
9. Specifična količina otpada koju proizvodi prosječni turist po noćenju
10. Ukupna količina proizvedenog otpada, količina proizvedenog otpada po stanovniku

Korigirani broj stanovnika predstavlja stalno stanovništvo Republike Hrvatske, odnosno administrativne jedinice, koje je obuhvaćeno sakupljanjem komunalnog otpada, te uvećano za ekvivalent broja stanovnika uslijed turističke gospodarske aktivnosti. Ekvivalent broja stanovnika uslijed turističke gospodarske aktivnosti u ovom radu računa se iz godišnjeg broja noćenja podijeljenog sa 365 dana. Rezultat je prosječni broj turista dnevno tokom jedne godine, što predstavlja ekvivalent broja ljudi koji su svakodnevno prisutni u nekoj administrativnoj jedinici. Ovaj broj se iznosom razlikuje od istog ekvivalenta iz Izvješća o komunalnom otpadu koji se temelji na podacima o masi komunalnog otpada od turizma.

Podaci za period 2009.-2013. prikupljeni su u prethodnim istraživanjima (Grbeš i dr., 2016, Grbeš 2017) korišteni su uz odobrenje autora, a u ovom radu prikupljeni su dodatni podaci za period 2014.-2017. Prikupljeni podaci nalaze se u Prilogu 1 ovog rada.

Izvori podataka su: Registri i izvješća Hrvatske agencije za okoliš i prirodu: HAOP (2014; 2015; 2016; 2017); popisni podatci i godišnja izvješća Državnog zavoda za statistiku: DZS (2011; 2012; 2013; 2014; 2015; 2016); te njihove procjene stanovništva za razdoblje od 2011. do 2017. godine.

Izvješća o komunalnom otpada (HAOP, 2014; 2015; 2016; 2017) objavljuje Hrvatska agencija za okoliš i prirodu na kraju svake godine za prethodnu godinu. Sadrže podatke o broju stanovnika obuhvaćenih organiziranim sakupljanjem otpada, broju noćenja turista i količini proizvedenog otpada, itd.

Izvješća za prosječnu mjesečnu neto plaću, broj zaposlenih u pravnim osobama i procijenjeni broj stanovnika izdaje Državni zavod za statistiku. Procjene broja stanovnika računaju se na temelju podataka iz Popisa stanovništva 2011., prirodnoga kretanja i migracijskog salda (DZS, 2017).

Za proračune modela odabrane su nezavisne varijable na temelju prethodnih istraživanja (Grbeš 2017, Grbeš i dr., 2016) koje su snažno korelirale s proizvodnjom komunalnog otpada:

1. Broj stanovnika – korištena je procjena DZS-a;
2. Dodatno stanovništvo – turistički ekvivalent odnosno broj turista dnevno tokom promatrane godine (broj turističkih noćenja podijeljen sa 365 dana u godini);
3. Ukupna godišnja neto plaća – umnožak prosječne mjesečne neto plaće zaposlenih u pravnim osobama, 12 mjeseci u godini i prosječnog broja zaposlenih u pravnim osobama u promatranoj godini.

Zavisna varijabla je ukupna količina proizvedenog komunalnog otpada tokom promatrane godine.

### **3.2. Deskriptivna statistika**

Standardna devijacija  $\sigma$  je mjera odstupanja vrijednosti slučajne varijable od aritmetičke sredine izraženo u mjernim jedinicama varijable (apsolutna mjera). Računa se kao pozitivni drugi korijen iz varijance - mjere disperzije koja je izražena u kvadratima mjernih jedinica varijable:

$$\sigma = +\sqrt{\sigma^2}. \quad (3-1)$$

Ako se standardna devijacija podijeli s aritmetičkom sredinom, a omjer pomnoži s posto, dobiveni pokazatelj je koeficijent varijacije  $V$  i relativna je mjera disperzije, izražena u %. Kod (višestruke) linearne regresije se koeficijent varijacije regresije računa prema formuli:

$$V = \frac{\hat{\sigma}}{\bar{y}} \cdot 100 \quad (3-2)$$

gdje je  $\bar{y}$  aritmetička sredina slučajnog uzorka zavisne varijable  $y$ , a  $\hat{\sigma}$  standardna greška regresije:

$$\hat{\sigma} = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n-k-1}} \quad (3-3)$$

gdje su:

$y_i$ - izmjerene vrijednosti

$\hat{y}_i$ - procijenjene vrijednosti

$n$  - broj izmjerenih podataka

$k$  - broj nezavisnih varijabli.

Standardna greška regresije interpretira se kao apsolutni pokazatelj reprezentativnosti regresijskog modela, a pokazuje prosječni stupanj varijacije izmjerenih vrijednosti slučajne varijable  $y$  u odnosu na procijenjene regresijske vrijednosti. Koeficijent varijacije je relativni pokazatelj reprezentativnosti regresijskog modela, a predstavlja postotak standardne greške regresije od aritmetičke sredine slučajnog uzorka varijable  $y$ . Koeficijent varijacije najčešće poprima vrijednost iz intervala  $[0, 100]$ . Što je bliže vrijednosti nula, to je disperzija podataka manja, a time i reprezentativnost modela veća. Koeficijent varijacije može poprimiti i vrijednost veću od 100%. To će se dogoditi kada je standardna greška regresije veća od aritmetičke sredine slučajnog uzorka, što ukazuje na

veliku heterogenost podataka, odnosno veliku disperziju. Postoji radno pravilo po kojem se varijabilnost mjerena koeficijentom varijacije većim od 30% smatra velikom, a reprezentativnost modela slabom (Bahovec i dr., 2016).

### **3.3. Metoda linearne regresije**

#### **3.3.1. Jednostavna linearna regresija**

Regresijska analiza je najčešće korištena metoda u empirijskim istraživanjima. Njome se želi kvantificirati odnos dviju (ili više) pojava. Postoji ključna razlika između regresijske i korelacijske analize. U korelacijskoj analizi se istražuje smjer i jakost povezanosti dviju slučajnih varijabli  $x$  i  $y$ . S druge strane, u regresijskoj se analizi želi procijeniti prosječna vrijednost jedne varijable  $y$  na temelju zadanih (fiksni) vrijednosti druge varijable  $x$ . Osnova regresijske analize je regresijski model. Regresijski model je hipotetički model (formula) kojim se izražava statistička (stohastička) povezanost između pojava. Na temelju uzoraka vrijednosti odabranih varijabli procjenjuju se parametri pretpostavljenog modela i testiraju pretpostavke kako bi se odredila adekvatnost procijenjenog modela. Ako je procijenjeni model adekvatan, koristi se za testiranje ekonomske teorije i u prognostičke svrhe. Cilj regresijske analize je da se na temelju  $n$  opažanja (mjerjenja) varijabli procijene nepoznati regresijski parametri (parametri populacije)  $\beta_0$  i  $\beta_1$ . U tu svrhu potrebno je uvesti teorijske pretpostavke o greškama relacije (slučajne varijable)  $\varepsilon$ . U analizi modela jednostavne linearne regresije pretpostavlja se da je model populacije (osnovnog skupa) linearan:

$$y = \beta_0 + \beta_1 x + \varepsilon \quad (3-4)$$

tj., da je veza između zavisne varijable  $y$  i nezavisne varijable  $x$  linearna (Bahovec i dr., 2016).

#### **3.3.2. Višestruka linearna regresija**

Model jednostavne linearne regresije, na temelju kojeg se analizira utjecaj jedne nezavisne varijable  $x$  na zavisnu varijablu  $y$ , često je neadekvatan u praksi. Realnije je pretpostaviti da će više varijabli utjecati na varijablu  $y$ . Potrebno je stoga prethodna razmatranja poopćiti

i analizirati zajednički utjecaj više nezavisnih varijabli na varijablu  $y$ . U modelu višestruke linearne regresije varijacije zavisne varijable  $y$  objašnjavat će se pomoću skupa od  $k$  nezavisnih varijabli  $x_1, x_2, \dots, x_k$ . I u ovom modelu se pretpostavlja da je  $y$  slučajna varijabla, dok se za varijable  $x_1, x_2, \dots, x_k$  pretpostavlja da su nestohastičke (fiksne), tj. da imaju iste vrijednosti u različitim uzorcima. Jednadžba modela glasi:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + \varepsilon, \quad (3-5)$$

s tim da je  $\varepsilon$  slučajna varijabla koja nije mjerljiva i njenim uključivanjem u obliku aditivnog člana model postaje stohastički (statistički). Kod višestruke linearne regresije koristi se korigirani koeficijent regresije (označen je u tablicama u Prilogu 2 kao „adjusted  $R^2$ “). Iako je označen kao kvadrat broja, ponekad može ispasti i negativan što u tom slučaju znači da regresijski model lošiji opisuje trend nego što bi to činio pravac (Bahovec i dr., 2016).

### **3.4. Hipoteze modela proizvodnje komunalnog otpada u Hrvatskoj u razdoblju 2009. – 2017.**

#### ***3.4.1. Hipoteze modela proizvodnje komunalnog otpada na temelju vremenskog trenda***

Proizvodnja komunalnog otpada u RH ima određeni trend i može se prikazati i prognozirati relativno stabilnom funkcijom koja ovisi samo o rednom broju promatrane godine. Svi efekti u društvu i gospodarstvu koji utječu na proizvodnju otpada se zanemaruju.

$$y_{M1} = f(t), \quad (3-6)$$

gdje su:

$y$  - količina proizvedenog komunalnog otpada;

$t$  (2009) = 1;  $t$  (2010) = 2;  $t$  (2011) = 3; itd.

### **3.4.2. Hipoteze modela proizvođača komunalnog otpada**

Komunalni otpad proizvodi stalno stanovništvo i turisti. Količina komunalnog otpada koju u jednoj godini proizvede stanovništvo RH može se izraziti kao specifična proizvodnja komunalnog otpada po stanovniku pomnožena s brojem stanovnika. Količina komunalnog otpada koju proizvode turisti može se izraziti kao umnožak specifične količine otpada po noćenju i broja noćenja turista. Ako se broj noćenja podijeli sa 365 dana, dobije se turistički ekvivalent rezidencijalnom stanovništvu koje također ima svoju prosječnu godišnju proizvodnju otpada po turističkom ekvivalentu stanovnika. Iako su stanovništvo i turisti glavni proizvođači komunalnog otpada, postoje i drugi čimbenici koje u ovom modelu zbirno prikazujemo kao broj  $C$  koji može i ne mora biti promjenjiv. Specifična količina komunalnog otpada nije ista za stanovnike i turiste.

$$y_{M2} = f(x_1, x_2) = ax_1 + bx_2 + C \quad (3-7)$$

gdje su:

$y$  - količina proizvedenog komunalnog otpada;

$a$  - koeficijent;

$b$  - koeficijent;

$C$  – vrijednost  $y_{M2}$  kada su vrijednosti varijabli  $x_1$  i  $x_2$  jednake nuli;

$x_1$  - broj stanovnika;

$x_2$  - turistički ekvivalent stanovnika.

### **3.4.3. Hipoteze ekonomskog modela nastanka otpada**

Komunalni otpad koji proizvodi stanovništvo ovisi o neto primanjima stanovništva koja se na godišnjoj razini mogu izraziti kroz prosječni broj zaposlenih u pravnim osobama pomnožen s prosječnom mjesečnom neto plaćom u godini dana (pomnoženo sa 12 mjeseci). Količina komunalnog otpada koju proizvodi stanovništvo može se izraziti kao specifična proizvodnja komunalnog otpada po stanovniku pomnožena s brojem stanovnika. Postoje i drugi, manje relevantni čimbenici koje u ovom modelu zbirno prikazujemo kao broj  $E$  koji može i ne mora biti promjenjiv.

$$y_{M3} = f(x_3) = dx_3 + E \quad (3-8)$$

gdje su:

$y$  - količina proizvedenog komunalnog otpada;

$x_3$  - ukupna godišnja neto plaća;

$d$  - koeficijent;

$E$  – vrijednost  $y_{M3}$  kada je vrijednost varijable  $x_3$  jednaka nuli.

### 3.5. Metodologija proračuna modela

Nezavisne ( $x_1, x_2, x_3$ ) i zavisne ( $y$ ) varijable unesu se u tablicu ulaznih podataka (tablica 3-1.) programa *Statistica*. Pristupi se proračunu deskriptivne statistike i matrice korelacija, a nakon toga se provede višestruka analiza regresije s kombinacijama varijabli kako je prikazano u sljedećoj tablici (tablica 3-2.).

Tablica 3-1. Ulazni podaci za statističke proračune

	$t$ God.	$y$ Proizvodnja komunalnog otpada (t)	$x_1$ Broj stanovnika	$x_2$ Turisti kao dodatno stanovništvo	$x_3$ Ukupna godišnja neto plaća (HRK)
1	2009	1.743.211	4.305.407	154.246	77.184.847.976
2	2010	1.629.915	4.290.819	154.565	74.882.594.233
3	2011	1.645.295	4.275.984	165.354	75.710.542.881
4	2012	1.670.005	4.262.140	171.900	75.824.922.612
5	2013	1.720.758	4.246.809	177.512	74.929.781.303
6	2014	1.637.371	4.225.316	182.148	74.403.883.680
7	2015	1.653.919	4.190.669	196.179	78.201.073.487
8	2016	1.679.765	4.154.213	290.939	80.296.372.829
9	2017	1.716.441	4.105.493	325.171	85.844.194.974

Tablica 3-2. Shema proračuna za (višestruku) linearnu regresiju u programu *Statistica*

Model	Zavisna varijabla	Nezavisne varijable	Model
1.	$y$	$x_1$	
2.	$y$	$x_2$	
3.	$y$	$x_3$	Ekonomski model
4.	$y$	$x_1, x_2$	Model proizvođača otpada
5.	$y$	$x_1, x_3$	
6.	$y$	$x_2, x_3$	
7.	$y$	$x_1, x_2, x_3$	

Cjelokupan proračun je prikazan u Prilozima 2 i 3 ovoga rada.




## 4. REZULTATI

### 4.1. Kretanja različitih društvenih i ekonomskih pokazatelja u periodu 2009. - 2017.


U ovom poglavlju prikazuju se kretanja različitih varijabli i pokazatelja kao što su: količina proizvedenog komunalnog otpada, broj stanovništva obuhvaćenog sakupljanjem otpada, prosječna mjesečna neto plaća, broj noćenja turista, godišnji prihod, broj stanovništva uvećanog za ekvivalentni broj turista, broj zaposlenih u pravnim osobama u promatranom vremenskom razdoblju i kontekstu.

Na slikama od 4-1. do 4-7. prikazani su grafovi kretanja određenih varijabli kroz godine (2009.-2017.) za Republiku Hrvatsku.




Slika 4-1. Kretanje količine proizvedenog komunalnog otpada u RH od 2009. do 2017.

Iz grafikona prikazanog na slici 4-1. vidi se da je komunalni otpad zenit svoje proizvodnje doživio 2009. godine. 2010. ga je pak bilo najmanje te od tada do 2013. raste, kada se 2014. bilježi pad od 4,8% u odnosu na 2013. i onda opet od 2014. do 2017. raste. Veliki rast 2013. može se pripisati kasnije spomenutom povećanju količine otpada od sanacije divljih odlagališta, otpadne zemlje i kamenja te otpadnog metala i papira.



Slika 4-2. Kretanje broja stanovništva obuhvaćenog sakupljanjem otpada u RH od 2009. do 2017.



Slika 4-3. Kretanje prosječne mjesečne neto plaće u RH od 2009. do 2017.

Grafikon na slici 4-2. pokazuje pad broja stanovništva, a s obzirom da je postotak stanovništva obuhvaćenog sakupljanjem otpada 99%, samim time je i broj stanovništva

obuhvaćenog sakupljanjem otpada u konstantnom padu. Podaci su temeljeni na procjenama stanovništva DZS-a. Procjene broja stanovnika izračunate su na temelju podataka iz Popisa stanovništva 2011., prirodnoga kretanja i migracijskog salda. (DZS, 2017)


Grafikon na slici 4-3. pokazuje rast prosječne mjesečne neto plaće. Pad je samo zabilježen od 2015. do 2016. godine.

Grafikon na slici 4-4. pokazuje kako je broj noćenja turista u porastu, a pogotovo od 2015. godine.


Grafikon na slici 4-5. pokazuje da do 2014. nije bilo većih odstupanja u godišnjoj neto plaći, a od 2014. raste, što je jedan od pokazatelja izlaska iz recesije.

Graf prikazan na slici 4-6. implicira kako bi porast turističke aktivnosti mogao imati efekte prividnog povećanja broja stanovnika.

Iz grafikona na slici 4-7. vidi se da je broj zaposlenih u pravnim osobama padao do 2014., te od tada raste, što se također povezuje s recesijom i izlaskom iz iste 2015.




Slika 4-4. Kretanje broja noćenja turista u RH od 2009. do 2017.



Slika 4-5. Kretanje godišnje neto plaće u RH od 2009 do 2017.



Slika 4-6. Kretanje broja stanovništva uvećanog za ekvivalentni broj turista u RH od 2009. do 2017.



Slika 4-7. Kretanje broja zaposlenih u pravnim osobama u RH od 2009. do 2017.

#### 4.2. Rezultati modela proizvodnje komunalnog otpada na temelju vremenskog trenda

Proizvodnja komunalnog otpada prikazana je i prognozirana funkcijom koja ovisi samo o vremenu (promatranoj godini).

$$y_{M1} = f(t) = 451t + 2000000 \quad (4-1)$$

gdje su:

$y$  - količina proizvedenog komunalnog otpada, u tonama;

$t$  (2009.) = 1;  $t$  (2010.) = 2;  $t$  (2011.) = 3; itd.

Koeficijent determinacije ( $R^2$  vrijednost) modela je 0,0009 što znači da proizvodnja komunalnog otpada ne ovisi linearno o vremenu te da je prognoziranje na temelju ovakvog modela neizvjesno. To također znači da je promatrani period obilježen vrlo varijabilnom proizvodnjom otpada.

#### 4.3. Rezultati modela proizvođača komunalnog otpada $f(x_1, x_2)$

Proizvodnja komunalnog otpada prikazana je i prognozirana funkcijom koja ovisi o broju stanovnika i turista prikazanih kao ekvivalent stanovništva u RH.

$$y_{M2} = f(x_1, x_2) = 1,111x_1 + 1,315x_2 - 1.359.728 \quad (4-2)$$

gdje su:

$y_{M2}$  - količina proizvedenog komunalnog otpada;

$x_1$  - broj stanovnika;

$x_2$  - turistički ekvivalent stanovnika.

Korigirani koeficijent determinacije ovoga modela je negativan što znači da model lošije opisuje trend nego što bi ga opisivao pravac. Koeficijent varijacije je 2,50%.

#### 4.4. Rezultati ekonomskog modela $f(x_3)$

Proizvodnja komunalnog otpada prikazana je i prognozirana funkcijom koja ovisi o broju zaposlenih u pravnim osobama i prosječnoj mjesečnoj neto plaći, tj. ukupnoj godišnjoj neto plaći.

$$y_{M3} = f(x_3) = 0,422x_3 + 1.314.348 \quad (4-3)$$

gdje su:

$y_{M3}$  - količina proizvedenog komunalnog otpada

$x_3$  - ukupna godišnja neto plaća, u kunama.

Koeficijent determinacije ovoga modela je 0,177, a koeficijent varijacije je 2,35%.

#### 4.5. Ostali rezultati regresijskih modela

Statistički proračuni su pokazali kako je od modela koji se temelje na pojedinačnim varijablama  $x_1$ ,  $x_2$ , odnosno  $x_3$  najprecizniji za predviđanje model koji se temelji na varijabli  $x_3$  (najveće vrijednosti koeficijenta determinacije  $R^2$ ). Među modelima koji se temelje na kombinaciji dviju nezavisnih varijabli ( $x_1, x_2$ , zatim  $x_1, x_3$ , odnosno  $x_2, x_3$ ) najprecizniji je model koji se temelji na varijablama  $x_1$  i  $x_3$ .

Tablica 4-1. Sumarni prikaz rezultata statističkih proračuna ( $y$  - proizvodnja komunalnog otpada (t),  $x_1$  - broj stanovnika,  $x_2$  - turisti kao dodatno stanovništvo,  $x_3$  - ukupna godišnja neto plaća (HRK))

Model	Zavisna varijabla	Nezavisne varijable	Model	$R^2$	Koeficijent varijacije (%)
1.	$y$	$x_1$	$y = -0,131x_1 + 2.014.590$	0,017	2,57
2.	$y$	$x_2$	$y = 0,267x_2 + 1.642.111$	0,071	2,50
3.	$y$	$x_3$	$y = 0,422x_3 + 1.314.348$	0,177	2,35
4.	$y$	$x_1, x_2$	$y = 1,111x_1 + 1,315x_2 - 1.359.728$	neg.	2,50
5.	$y$	$x_1, x_3$	$y = 0,719x_1 + 1,021x_3 - 1.056.320$	0,115	2,28
6.	$y$	$x_2, x_3$	$y = -0,663x_2 + 1,024x_3 + 883.378$	0,006	2,42
7.	$y$	$x_1, x_2, x_3$	$y = 0,910x_1 + 0,311x_2 + 0,897x_3 - 1.481.472$	neg.	2,49

Regresijski model koji se temelji na varijablama  $x_1$  i  $x_2$  (Model 4) te model koji se temelji na varijablama  $x_1$ ,  $x_2$  i  $x_3$  (Model 7) rezultiraju negativnim korigiranim koeficijentima determinacije što znači da ti modeli manje dobro opisuju trend nego što bi to činio pravac.

Modeli s najvišim (korigiranim) koeficijentima determinacije su Model 3 koji se temelji na varijabli  $x_3$  (ukupna godišnja neto plaća) i Model 5 koji se temelji na varijablama  $x_1$  (broj stanovnika) i  $x_3$  (ukupna godišnja neto plaća). Ti modeli ujedno imaju i najmanje koeficijente varijacije regresije (tablica 4-1.).

## **5. DISKUSIJA REZULTATA**

Vremenski period od 2009. do 2017. u RH obilježen je sustavnim radom na poboljšanju gospodarenja otpadom, ali i gospodarskom krizom, promjenama zaposlenosti i broja stanovnika, investicijama u turizmu, oporavkom od krize i rastom gospodarstva koji se preko određenih varijabla mogu iščitati u prethodnom poglavlju na grafikonima prikazanim na slikama (4-1. do 4-7.).

### **5.1. Promjene u sustavu gospodarenja otpadom**

Porast količine komunalnog otpada bilježi se do 2008. godine kada je zapravo i počela globalna gospodarska kriza nakon čega slijedi smanjenje prijavljenih količina komunalnog otpada do 2010. godine. U 2011. godini ponovo se bilježi lagani porast proizvodnje komunalnog otpada koji je najvjerojatnije posljedica primjene druge metodologije izračuna odnosno pribrajanja komunalnog otpada nastalog u uslužnom sektoru (ambalažni otpad, otpadni papir i karton, baterije, akumulatori itd.). Od 2011. također sve općine i gradovi imaju organizirano skupljanje i odvoz komunalnog otpada. Unatoč laganom porastu ukupnih količina komunalnog otpada od 2011. koji je najvjerojatnije posljedica pribrajanja komunalnog otpada nastalog u uslužnom sektoru, ipak se može govoriti o nastavku padajućeg trenda količina komunalnog otpada iz kućanstava (HAOP, 2018). U 2013. godini zabilježene su nešto veće vrijednosti komunalnog otpada uslijed povećane količine otpada od sanacije divljih odlagališta, otpadne zemlje i kamenja te otpadnog metala i papira (HAOP, 2018). Sukladno uputi Eurostat-a, od 2015. godine kod izračuna količina više se ne uzimaju u obzir sljedeće vrste otpada: 20 02 02 (zemlja i kamenje), 20 03 04 (muljevi iz septičkih jama) i 20 03 06 (otpad nastao čišćenjem kanalizacije). Ukupna količina tog otpada 2009. je iznosila 25 000 tona nakon čega je padala i 2014. iznosila 13 000 tona (HAOP, 2018).

Količine komunalnog otpada koji nastaje u turizmu su porasle u razdoblju od 2014. do 2017. godine za 61% kao posljedica porasta broja turističkih noćenja. Taj podatak utvrđuje se korištenjem priručnika „Methodological work on measuring the sustainable development of tourism, Part 2: Manual on sustainable development indicators of tourism“, European Commission, 2006 (HAOP, 2018).



U Izvješćima o komunalnom otpadu, proizvedeni komunalni otpad djelomično se procjenjuje (oko 15%). Podaci o sakupljenom komunalnom otpadu (bez dodane procijenjene vrijednosti) koji su uzimani u dosadašnjim sličnim radovima (kao npr. u radovima Ljubić 2015, Grbeš i dr., 2016, Grbeš 2017) zapravo pokazuju konstantan pad količine otpada za razliku od varijable proizvodnja komunalnog otpada koja ima potpuno drugačiji trend.


Iz svega navedenog može se zaključiti da podaci o komunalnom otpadu dosta variraju i imaju određene sustavne nedostatke koji mogu utjecati na kvalitetu dobivenih modela i prognoze na temelju tih modela.

## **5.2. Kretanje populacije koja proizvodi komunalni otpad**


Komunalni otpad kao proizvod ljudske svakodnevne potrošnje nastaje od stalnog i od povremenog stanovništva. Kao povremeno stanovništvo, u ovom radu identificirani su turisti. Stalno stanovništvo i broj stanovnika obuhvaćenih sakupljanjem komunalnog otpada pokazuju odstupanja u kretanju.

Slike 5-1. i 5-2. daju usporedni prikaz populacija koje proizvode komunalni otpad i to na sljedeći način. Na slici 5-1. uspoređuju se stanovništvo prema procjeni DZS-a i obuhvat stanovništva sakupljanjem komunalnog otpada (Izvješća o komunalnom otpadu); a na slici 5-2. turistički ekvivalent stanovništva izračunat na dva načina: prema proračunu turističkog ekvivalenta stanovništvu na temelju broja noćenja (kako je objašnjeno u ovom radu) te prema proračunu turističkog ekvivalenta stanovništvu na temelju količine otpada od turizma, prema podacima iz Izvješća o komunalnom otpadu (dostupno za razdoblje od 2014. do 2017). Izvješća o komunalnom otpadu stanovništvo obuhvaćeno organiziranim sakupljanjem otpada računaju prema popisu stanovništva iz 2011. što se dosta razlikuje ako se računa prema procijenjenom stanovništvu DZS-a. Također se iz Izvješća tijekom godina može iščitati kako je broj stanovnika obuhvaćenih organiziranim sakupljanjem komunalnog otpada veći no što je broj stanovnika prema procjeni DZS-a.

Obzirom da se podaci o populacijama koje proizvode otpad procjenjuju odnosno računaju, te da administrativno kasne u praćenju stvarnog kretanja broja stanovništva, može se zaključiti kako i ovaj sustav podataka ima određenu grešku koja utječe na kvalitetu modeliranja.



Slika 5-1. Broj stanovnika RH i stanovništvo obuhvaćeno sakupljanjem komunalnog otpada



Slika 5-2. Turistički ekvivalent stanovništva prema dva različita načina proračuna

### 5.3. Modeli proizvodnje komunalnog otpada

Provedene analize nisu potvrdile pretpostavke modela proizvođača komunalnog otpada (jednadžba 4-2; Model 4, tablica 4-1.). Rezultati su pokazali da taj model lošije aproksimira trend no što bi to činio pravac. Stoga se može zaključiti kako hipoteze modela proizvođača komunalnog otpada (potpoglavlje 3.4.2.) nisu potvrđene. Nasuprot tome, ekonomski model proizvodnje komunalnog otpada (jednadžba 4-3; Model 3, tablica 4-1.) najreprezentativniji je od svih računatih modela s jednom varijablom, s najvišim koeficijentom determinacije (0,177) i najnižim koeficijentom varijacije (2,35%). Hipoteze toga modela, navedene u potpoglavlju 3.4.3. su potvrđene. Neočekivani model koji je rezultirao iz provedenih analiza je Model 5 koji se temelji na varijablama broj stanovnika i ukupna godišnja neto plaća.

Na temelju rezultata mogu se preporučiti sljedeći regresijski modeli proizvodnje komunalnog otpada u Hrvatskoj:

Model 3: ekonomski model proizvodnje komunalnog otpada

$$y = 0,422x_3 + 1.314.348 \quad (4-3)$$

Model 5: populacijsko-ekonomski model proizvodnje komunalnog otpada

$$y = 0,719x_1 + 1,021x_3 - 1.056.320 \quad (5-1)$$

gdje su:

$y$  - količina proizvedenog komunalnog otpada (t);

$x_1$  - broj stanovnika;

$x_3$  - ukupna godišnja neto plaća.

Ukupna godišnja neto plaća je podatak koji u sebi sadrži i podatak o broju zaposlenih i podatak o prosječnoj mjesečnoj neto plaći što na razini sustava dovoljno dobro opisuje potrošačku sposobnost sustava, a time i sposobnost stvaranja komunalnog otpada. Izvjesno je da bi u drugim okolnostima trebalo tražiti drukčiji pokazatelj kupovne moći, npr. u situaciji kada zaposlenost u pravnim osobama nije glavni izvor primanja značajnog broja stanovnika, u slučaju velike nezaposlenosti ili kod drukčijih načina prihodovanja.

Prisutnost broja stanovnika kao varijable u Modelu 5 (populacijsko-ekonomski model proizvodnje komunalnog otpada) sugerira da se broj stanovnika isplati pratiti kao jednu od kvalitetnih varijabli prognoziranja proizvodnje otpada.

Turistički ekvivalent stanovništva koji u ovom radu predstavlja dodatno stanovništvo koje vjerojatno utječe na proizvodnju otpada ipak se nije pokazao dobrim prediktorom. U Modelima 2 i 6 gdje je varijabla turistički ekvivalent stanovništva uključena, koeficijent determinacije (0,071) odnosno korigirani koeficijent (0,006) su premali, što znači da ni jedan niti drugi model nisu reprezentativni.

## 6. ZAKLJUČAK

U ovom radu prikupljeni su i analizirani podaci o otpadu iz godišnjih izvješća o komunalnom otpadu HAOP-a, te podaci o prosječnim mjesečnim neto plaćama i broju zaposlenih u pravnim osobama iz DZS-a za razdoblje do 2009. do 2017. godine. Cilj istraživanja bio je izraditi i usporediti različite modele proizvodnje otpada u RH.

Izrađeni su različiti regresijski modeli za predviđanje proizvedene količine komunalnog otpada u RH na temelju tri nezavisne varijable: broj stanovnika, turistički ekvivalent stanovnika i ukupna godišnja neto plaća zaposlenih u pravnim osobama. Kao najprecizniji modeli pokazali su se:

Model 3: ekonomski model proizvodnje komunalnog otpada

$$y = 0,422x_3 + 1.314.348$$

Model 5: populacijsko-ekonomski model proizvodnje komunalnog otpada

$$y = 0,719x_1 + 1,021x_3 - 1.056.320.$$

Ostaje pratiti i eventualno korigirati modele u budućim razdobljima. Kako bi predviđanje proizvodnje komunalnog otpada bilo što preciznije potrebno je unaprijediti metodologiju prikupljanja raznih podataka o otpadu i stanovništvu, jer su dosadašnji manjkavi zbog nedostupnosti i nepreciznosti podataka. Time će se omogućiti optimizacija modela u budućim istraživanjima.

### *Preporuke*

- Potrebno je nastaviti i poboljšati kontinuirano praćenje sustava gospodarenja komunalnim otpadom, promatrati ga kroz dulje vrijeme ili na drugi način (direktnim mjerenjem) efekte promjena u sustavu kvantificirati prilikom modeliranja.
- Potrebno je ažurnije pratiti kretanje broja stanovnika kao i postići kvalitetnije praćenje broja turista. Potrebno je i istražiti ili utvrditi stvarnu prosječnu proizvodnju komunalnog otpada, posebno stanovnika, a posebno turista, što će doprinijeti kvalitetnijim prognozama.
- Kroz dulje vrijeme treba promatrati trendove zaposlenosti, plaća i nastanka otpada.
- Potrebno je istražiti druge sociološko-demografske i ekonomske čimbenike koji utječu na odluke i ponašanje potrošača u pogledu gospodarenja otpadom.

## LITERATURA

Bahovec V., Dumičić K., Erjavec N., Čižmešija M., Kurnoga N., Arnerić J., Čeh Časni A., Jakšić S., Sorić P., Žmuk B., Palić I., Lolić I., 2016. Statistika. 2. izdanje. ELEMENT.

Beigl, P., Lebersorger, S., Salhofer, S., 2008. Modelling municipal solid waste generation: A review. *Waste Management* 28, str. 200-214.

Campbell, I., Chopra, M., & Rudan, I., 31. srpanj 2017. Survival: The Story of Global Health. Centre for Global Health Research, The Usher Institute, The University of Edinburgh. URL: <https://www.youtube.com/watch?v=IX7PH8ofmGk>

Chen, M., Giannis, A., Wang, J. Y., 2012. Application of system dynamics model for municipal solid waste generation and landfill capacity evaluation in Singapore. *The Macrotheme Review* 1, str. 101-114.

Chung, S. S., 2010. Projecting municipal solid waste: The case of Hong Kong SAR. *Resources, Conservation and Recycling* 54, str. 759-768.

Dai, C., Li, Y. P., Huang, G. H., 2011. A two-stage support- vector-regression optimization model for municipal solid waste management- A case study of Beijing, China. *Journal of Environmental Management* 92, str. 3023-3037.

Damjanić, Z., 2013. Socio-demografski aspekti odnosa prema zbrinjavanju kućnog otpada na otoku Krku. *Zbornik Ekonomskog fakulteta u Zagrebu*, str. 99-119. URL: <https://hrcak.srce.hr/104656>

Državni zavod za statistiku Republike Hrvatske. 2011a. Popis stanovništva, kućanstava i stanova 2011.godine. Kućanstva i obitelji. 1583. ISSN 1333-1876.

Državni zavod za statistiku Republike Hrvatske. 2011b. Priopćenje. Zaposleni po područjima djelatnosti I županijama stanje 31. Ožujka 2010. Zagreb XLVII 9.2.4. ISSN 1330-0350.

Državni zavod za statistiku Republike Hrvatske. 2011c. Privatna kućanstva prema broju članova, popis 2011.

Državni zavod za statistiku Republike Hrvatske. 2011f. Zbirni pregledi: Županije, površina, stanovništvo, gradovi, općine i naselja.

Državni zavod za statistiku Republike Hrvatske. 2018. prosječne mjesečne neto plaće i broj zaposlenih u pravnim osobama po županijama za 2014., 2015. i 2016. godinu.

Državni zavod za statistiku Republike Hrvatske. 2017. procjene stanovništva za razdoblje od 2011. do 2017. godine.

Erdelez, A. M., 2007. Integralni pristup upravljanju sustavom prikupljanja komunalnog otpada. Građevinar, str. 505-516. URL: <https://hrcak.srce.hr/16457>

European Commission - Environment, 13. studeni 2018. European Commission - Environment. URL: <http://ec.europa.eu/environment/waste/index.htm> (5.1.2019)

European Environment Agency, 14. studeni 2016. European Environment Agency. URL: <https://www.eea.europa.eu/themes/waste/municipal-waste> (5.1.2019)

European Parliament and Council, 2012. DIRECTIVE 2012/18/EU. URL: <https://eur-lex.europa.eu/LexUriServ/LexUriServ.do?uri=OJ:L:2012:197:0001:0037:EN:PDF>

Fundurulja, D., Mužinić, M., & Pletikapić, Z., 2000. Odlagališta komunalnog otpada na području Hrvatske. Građevinar, str. 727-734. URL: <https://hrcak.srce.hr/13066>

Grbeš, A., Ljubić, I., Veinović, Ž. 2016. Study of correlations of statistical parameters with collected municipal solid waste in Croatia in period 2009–2013. Conference Proceedings of SEM2016. Zagreb : University of Zagreb, Faculty of Chemical Engineering and Technology, 2016., str. 51-60.

Grbeš, A., 2017. Odabir varijabli za stvaranje modela obradbe krutog otpada u gradovima i naseljima Hrvatske. Rudarsko-geološko-naftni zbornik, str. 69-69. URL: <https://doi.org/10.17794/rgn.2017.3.6>

Grbeš, A., Ljubić, I., Veinović, Ž. Municipal solid waste generation mechanism: a case study for Croatia in period 2009-2013. (neobjavljen rad)

Hrvatska agencija za okoliš i prirodu. 2015. Izvješće o komunalnom otpadu za 2014. godinu.

Hrvatska agencija za okoliš i prirodu. 2016. Izvješće o komunalnom otpadu za 2015. godinu.

Hrvatska agencija za okoliš i prirodu. 2017. Izvješće o komunalnom otpadu za 2016. godinu.

Hrvatska agencija za okoliš i prirodu. 2018. Izvješće o komunalnom otpadu za 2017. godinu.

Keser, S., Duzgun, S., Aksoy, A., 2012. Application of spatial and non-spatial data analysis in determination of the factors that impact municipal solid waste generation rates in Turkey. *Waste Management* 32, str. 359–371.

Kolekar, K. A., Hazra, T., & Chakrabarty, S., 2016. A review of prediction of municipal solid waste generation models. *International Conference on Solid Waste Management, 5IconSWM 2015. Procedia Environmental Science* 35, URL: <https://www.sciencedirect.com/science/article/pii/S1878029616301761> (6.1.2019)

Lebersorger, S., Beigl, P., 2011. Municipal solid waste generation on municipalities: Quantifying impacts of household structure, commercial waste and domestic fuel. *Waste Management* 31, str. 1907-1915.

Ljubić, I., 2015. Analiza sustava prikupljanja komunalnog otpada u Republici Hrvatskoj u 2013.godini. RGNF, Zagreb. URL: <https://repozitorij.rgn.unizg.hr/islandora/object/rgn%3A29/datastream/PDF/view>

Mustapić, M., 2010. Uloga lokalne zajednice u rješavanju problema odlaganja komunalnoga otpada u tranzicijskoj Hrvatskoj. *Kroatologija*, str. 199-212. URL: <https://hrcak.srce.hr/60212>

Narodne novine br. 130/2005. Strategija gospodarenja otpadom Republike Hrvatske. Zagreb: Narodne novine d.d. URL: [https://narodne-novine.nn.hr/clanci/sluzbeni/full/2005\\_11\\_130\\_2398.html](https://narodne-novine.nn.hr/clanci/sluzbeni/full/2005_11_130_2398.html)

Narodne novine br. NN 94/2013. Zakon o održivom gospodarenju otpadom. Zagreb: Narodne novine d.d. URL: [https://narodne-novine.nn.hr/clanci/sluzbeni/2013\\_07\\_94\\_2123.html](https://narodne-novine.nn.hr/clanci/sluzbeni/2013_07_94_2123.html)

Narodne novine br. NN 117/2017. Pravilnik o gospodarenju otpadom. Zagreb: Narodne novine d.d. URL: [https://narodne-novine.nn.hr/clanci/sluzbeni/2017\\_11\\_117\\_2708.html](https://narodne-novine.nn.hr/clanci/sluzbeni/2017_11_117_2708.html)

Narodne novine br. NN 90/2015. Pravilnik o katalogu otpada. Zagreb: Narodne novine d.d. URL: [https://narodne-novine.nn.hr/clanci/sluzbeni/2015\\_08\\_90\\_1757.html](https://narodne-novine.nn.hr/clanci/sluzbeni/2015_08_90_1757.html)



Narodne novine br. NN 69/2016. Pravilnik o građevnom otpadu i otpadu koji sadrži azbest.  
Zagreb: Narodne novine d.d. URL: [https://narodne-novine.nn.hr/clanci/sluzbeni/2016\\_07\\_69\\_1650.html](https://narodne-novine.nn.hr/clanci/sluzbeni/2016_07_69_1650.html)

Oumarou, M. B., Dauda, M., Abdulrahim, A. T., Abubakar, A. B., 2012. Municipal solid waste generation, recovery and recycling: A case study. World Journal of Engineering and Pure and Applied Science 2 (5), str.143-147.

Sobota, I., 2017. Tailings disposal. Dubrovnik International ESEE Mining School – DIM ESEE 2017.

Stanić, S., Buzov, I. i Galov, M., 2009. Prakse urbanog stanovništva u zbrinjavanju kućanskog otpada. Socijalna ekologija, 18 (2), str. 130-156. URL: <https://hrcak.srce.hr/41138>

Thanh, N. P., Matsui, Y., Fujiwara, T., 2010. Household solid waste generation and characteristic in a Mekong Delta city, Vietnam. Journal

UN. 1987. Report of the World Commission on Environment and Development: Our Common Future. URL: <http://www.un-documents.net/wced-ocf.htm> (5.1.2019)

## **PRILOZI**

Prilog 1: Tablica društvenih i ekonomskih pokazatelja 2009. - 2017.

Prilog 2: Proračuni modela u *Statistici*

Prilog 3: Proračuni koeficijenata varijacije regresije

**Prilog 1: Tablica društvenih i ekonomskih pokazatelja 2009. - 2017.**

Tablica društvenih i ekonomskih pokazatelja 2009. - 2017.

Godina	Broj stanovnika (Popis 2011)	Broj stanovnika prema procjeni DZS-a	Zaposleni u pravnim osobama	Prosječna mjesečna neto plaća (HRK)	Godišnja neto plaća	Broj noćenja turista	Proizvedeni komunalni otpad (t)	Količina proizvedenog komunalnog otpada po stanovniku (kg)	Turisti kao ekvivalent stanovništva	Stanovništvo + turisti	Otpad po broju stanovnika i turista	Količina komunalnog otpada iz turizma (t)	Količina proizvedenog otpada po turistu (kg)	Specifična količina otpada koju proizvodi prosječni turist po noćenju	specifična masa otpada po kuni iz neto godišnje plaće (kg)	Broj stanovnika obuhvaćen organiziranim sakupljanjem otpada (izvješća)	Turisti kao ekvivalent stanovništva (izvješća)
2009 (1)	4284889	4305407	1211085	5311	77184847976	56299647	1743211	405	154246	4459652	391				0,023	4283206	
2010 (2)	4284889	4290819	1168179	5342	74882594233	56416379	1629915	380	154565	4445385	367				0,022	4251102	
2011 (3)	4284889	4275984	1159657	5441	75710542881	60354275	1645295	385	165354	4441338	370				0,022	4247269	
2012 (4)	4284889	4262140	1153494	5478	75824922612	62743463	1670005	392	171900	4434040	377				0,022	4260995	
2013 (5)	4284889	4246809	1132246	5515	74929781303	64791814	1720758	405	177512	4424321	389				0,023	4194527	
2014 (6)	4284889	4225316	1120507	5534	74403883680	66483948	1637371	388	182148	4407464	371	88844	488	1,3	0,022	4233114	232576
2015 (7)	4284889	4190669	1141222	5710	78201073487	71605300	1653919	395	196179	4386848	377	98960	504	1,4	0,021	4233491	256374
2016 (8)	4284889	4154213	1177004	5685	80296372829	106192805	1679765	404	290939	4445152	378	139535	480	1,3	0,021	4245814	355956
2017 (9)	4284889	4105493	1195385	5984	85844194974	118687288	1716441	418	325171	4430664	387	155958	480	1,3	0,020	4238348	374899

## **Prilog 2: Proračuni modela u *Statistici***

## Ulazni podaci

	$t$ Godina	$y$ Proizvodnja komunalnog otpada (t)	$x_1$ Broj stanovnika	$x_2$ Turisti kao dodatno stanovništvo	$x_3$ Ukupna godišnja neto plaća (HRK)
1	2009	1.743.211	4.305.407	154.246	77.184.847.976
2	2010	1.629.915	4.290.819	154.565	74.882.594.233
3	2011	1.645.295	4.275.984	165.354	75.710.542.881
4	2012	1.670.005	4.262.140	171.900	75.824.922.612
5	2013	1.720.758	4.246.809	177.512	74.929.781.303
6	2014	1.637.371	4.225.316	182.148	74.403.883.680
7	2015	1.653.919	4.190.669	196.179	78.201.073.487
8	2016	1.679.765	4.154.213	290.939	80.296.372.829
9	2017	1.716.441	4.105.493	325.171	85.844.194.974


## Deskriptivna statistika

Variable	Descriptive Statistics (Spreadsheet1)				
	Valid N	Mean	Minimum	Maximum	Std.Dev.
$y$	9	1.677.409	1.629.915	1.743.211	40.674
$x_1$	9	4.228.539	4.105.493	4.305.407	66.718
$x_2$	9	202.001	154.246	325.171	62.137
$x_3$	9	77.475.357.108	74.403.883.680	85.844.194.974	3.658.576.645

## Matrica korelacija

Variable	Correlations (Spreadsheet1) Marked correlations are significant at $p < ,05000$ N=9 (Casewise deletion of missing data)					
	Means	Std.Dev.	$y$	$x_1$	$x_2$	$x_3$
$y$	1.677.408,889	40.673,573	1,000	-0,131	0,267	0,422
$x_1$	4.228.538,907	66.718,203	-0,131	1,000	-0,944	-0,833
$x_2$	202.001,497	62.137,256	0,267	-0,944	1,000	0,908
$x_3$	77.475.357.108,157	3.658.576.645,171	0,422	-0,833	0,908	1,000

# Graphical Summary (Y X1 X2 X3)



N: 9  
Mean: 1677409  
Median: 1670005  
Min: 1629915  
Max: 1743211  
L-Qrt: 1645295  
U-Qrt: 1716441  
Variance: 1.65e+009  
SD: 40674  
Std.Err: 13558  
Skw: 0.497  
Kurt: -1.280  
95% Conf SD  
Lower: 27473  
Upper: 77921  
95% Conf Mean  
Lower: 1646144  
Upper: 1708673

N: 9  
Mean: 4228539  
Median: 4246809  
Min: 4105493  
Max: 4305407  
L-Qrt: 4190669  
U-Qrt: 4275984  
Variance: 4.45e+009  
SD: 66718  
Std.Err: 22239  
Skw: -0.802  
Kurt: -0.270  
95% Conf SD  
Lower: 45065  
Upper: 127817  
95% Conf Mean  
Lower: 4177255  
Upper: 4279823


N: 9  
Mean: 202001  
Median: 177512  
Min: 154246  
Max: 325171  
L-Qrt: 165354  
U-Qrt: 196179  
Variance: 3.86e+009  
SD: 62137  
Std.Err: 20712  
Skw: 1.512  
Kurt: 0.929  
95% Conf SD  
Lower: 41971  
Upper: 119041  
95% Conf Mean  
Lower: 154239  
Upper: 249764

N: 9  
Mean: 7.75e+010  
Median: 7.58e+010  
Min: 7.44e+010  
Max: 8.58e+010  
L-Qrt: 7.49e+010  
U-Qrt: 7.82e+010  
Variance: 1.34e+019  
SD: 3.66e+009  
Std.Err: 1.22e+009  
Skw: 1.759  
Kurt: 3.146  
95% Conf SD  
Lower: 2.47e+009  
Upper: 7.01e+009  
95% Conf Mean  
Lower: 7.47e+010  
Upper: 8.03e+010

Analiza regresije za  $y = f(x_1)$

N=9	Regression Summary for Dependent Variable: Y (Spreadsheet1) R= ,13079918 R2= ,01710842 Adjusted R2= ----- F(1,7)=,12184 p					
	b*	Std.Err. of b*	b	Std.Err. of b	t(7)	p-value
Intercept			2.014.590,073	966.073,462	2,085	0,075
$x_1$	-0,131	0,375	-0,080	0,228	-0,349	0,737

Predicted & Residual Values Y									
	Observed Value	Predicted Value	Residual	Standard Pred. v.	Standard Residual	Std.Err. Pred.Val	Mahalanobis Distance	Deleted Residual	Cook's Distance
1	1.743.211,000	1.671.279,500	71.931,500	-1,152	1,669	22.689,727	1,327	99.495,281	0,738
2	1.629.915,000	1.672.442,625	-42.527,625	-0,933	-0,987	20.221,219	0,871	-54.525,066	0,176
3	1.645.295,000	1.673.625,625	-28.330,625	-0,711	-0,657	17.998,627	0,506	-34.312,027	0,055
4	1.670.005,000	1.674.729,500	-4.724,500	-0,504	-0,110	16.291,075	0,254	-5.511,653	0,001
5	1.720.758,000	1.675.952,000	44.806,000	-0,274	1,039	14.963,284	0,075	50.943,965	0,084
6	1.637.371,000	1.677.665,875	-40.294,875	0,048	-0,935	14.388,289	0,002	-45.346,617	0,062
7	1.653.919,000	1.680.428,625	-26.509,625	0,568	-0,615	16.772,611	0,322	-31.238,646	0,040
8	1.679.765,000	1.683.335,625	-3.570,625	1,114	-0,083	22.243,361	1,241	-4.866,224	0,002
9	1.716.441,000	1.687.220,500	29.220,500	1,844	0,678	31.568,549	3,401	63.012,469	0,573






Analiza regresije za  $y = f(x_2)$

N=9	Regression Summary for Dependent Variable: Y (Spreadsheet1) R= ,26695056 R2= ,07126260 Adjusted R2= ----- F(1,7)=,53711 p					
	b*	Std.Err. of b*	b	Std.Err. of b	t(7)	p-value
Intercept			1.642.111,248	50.147,440	32,746	0,000
$x_2$	0,267	0,364	0,175	0,238	0,733	0,487


Predicted & Residual Values Y								
	Observed Value	Predicted Value	Residual	Standard Pred. v.	Standard Residual	Std.Err. Pred.Val	Mahalanobis Distance	Cook's Distance
1	1.743.211,000	1.669.064,000	74.147,000	-0,769	1,769	18.020,916	0,591	90.971,852
2	1.629.915,000	1.669.119,875	-39.204,875	-0,763	-0,936	17.972,834	0,583	-48.042,840
3	1.645.295,000	1.671.005,125	-25.710,125	-0,590	-0,614	16.475,824	0,348	-30.411,471
4	1.670.005,000	1.672.149,000	-2.144,000	-0,484	-0,051	15.703,972	0,235	-2.494,317
5	1.720.758,000	1.673.129,625	47.628,375	-0,394	1,137	15.139,309	0,155	54.778,484
6	1.637.371,000	1.673.939,625	-36.568,625	-0,320	-0,873	14.748,292	0,102	-41.738,918
7	1.653.919,000	1.676.391,500	-22.472,500	-0,094	-0,536	14.036,797	0,009	-25.312,818
8	1.679.765,000	1.692.949,875	-13.184,875	1,431	-0,315	25.392,270	2,049	-20.835,516
9	1.716.441,000	1.698.931,375	17.509,625	1,982	0,418	32.519,615	3,929	44.022,367



Analiza regresije za  $y = f(x_3)$

N=9	Regression Summary for Dependent Variable: Y (Spreadsheet1) R= ,42151710 R2= ,17767667 Adjusted R2= ,06020190 F(1,7)=1,5125 p					
	b*	Std.Err. of b*	b	Std.Err. of b	t(7)	p-value
Intercept			1.314.348,427	295.505,824	4,448	0,003
$x_3$	0,422	0,343	0,000	0,000	1,230	0,258


Predicted & Residual Values Y									
	Observed Value	Predicted Value	Residual	Standard Pred. v.	Standard Residual	Std.Err. Pred.Val	Mahalanobis Distance	Deleted Residual	Cook's Distance
1	1.743.211,000	1.676.047,500	67.163,500	-0,079	1,703	13.189,952	0,006	75.625,992	0,206
2	1.629.915,000	1.665.258,875	-35.343,875	-0,709	-0,896	16.442,449	0,502	-42.783,480	0,102
3	1.645.295,000	1.669.138,750	-23.843,750	-0,482	-0,605	14.763,833	0,233	-27.731,646	0,035
4	1.670.005,000	1.669.674,750	330,250	-0,451	0,008	14.570,484	0,204	382,477	0,000
5	1.720.758,000	1.665.480,000	55.278,000	-0,696	1,402	16.335,046	0,484	66.730,680	0,246
6	1.637.371,000	1.663.015,500	-25.644,500	-0,840	-0,650	17.598,965	0,705	-32.024,072	0,066
7	1.653.919,000	1.680.809,750	-26.890,750	0,198	-0,682	13.431,167	0,039	-30.420,414	0,035
8	1.679.765,000	1.690.628,625	-10.863,625	0,771	-0,276	16.979,273	0,595	-13.336,631	0,011
9	1.716.441,000	1.716.626,500	-185,500	2,287	-0,005	34.491,191	5,232	-789,929	0,000



Analiza višestruke regresije za  $y = f(x_1, x_2)$

N=9	Regression Summary for Dependent Variable: Y (Spreadsheet1) R= ,45370216 R2= ,20584565 Adjusted R2= ----- F(2,6)=,77760 p					
	b*	Std.Err. of b*	b	Std.Err. of b	t(6)	p-value
	Intercept		-1.359.727,845	2.977.354,367	-0,457	0,664
	x <sub>1</sub>	1,111	0,677	0,671	1,008	0,352
	x <sub>2</sub>	1,315	0,861	0,721	1,194	0,277


Predicted & Residual Values Y									
	Observed Value	Predicted Value	Residual	Standard Pred. v.	Standard Residual	Std.Err. Pred.Val	Mahalanobis Distance	Deleted Residual	Cook's Distance
1	1.743.211,000	1.688.341,000	54.870,000	0,592	1,311	26.257,070	2,260	90.480,656	0,613
2	1.629.915,000	1.678.738,875	-48.823,875	0,072	-1,167	20.328,395	0,998	-63.897,684	0,183
3	1.645.295,000	1.677.982,375	-32.687,375	0,031	-0,781	17.851,621	0,566	-39.956,344	0,055
4	1.670.005,000	1.674.244,125	-4.239,125	-0,171	-0,101	15.822,176	0,254	-4.945,954	0,001
5	1.720.758,000	1.668.694,875	52.063,125	-0,472	1,244	15.747,731	0,244	60.649,156	0,099
6	1.637.371,000	1.658.133,125	-20.762,125	-1,045	-0,496	21.510,705	1,224	-28.214,936	0,040
7	1.653.919,000	1.646.753,375	7.165,625	-1,661	0,171	32.564,676	3,954	18.158,105	0,038
8	1.679.765,000	1.703.654,500	-23.889,500	1,422	-0,571	27.494,018	2,563	-42.023,992	0,145
9	1.716.441,000	1.700.137,750	16.303,250	1,232	0,390	32.502,682	3,936	41.073,699	0,194



Analiza višestruke regresije za  $y = f(x_1, x_3)$

N=9	Regression Summary for Dependent Variable: Y (Spreadsheet1) R= ,57979465 R2= ,33616183 Adjusted R2= ,11488245 F(2,6)=1,5192 p					
	b*	Std.Err. of b*	b	Std.Err. of b	t(6)	p-value
	Intercept		-1.056.320,741	2.001.413,970	-0,528	0,617
	x <sub>1</sub>	0,719	0,601	0,439	1,197	0,277
	x <sub>3</sub>	1,021	0,601	0,000	1,698	0,140


Predicted & Residual Values Y									
	Observed Value	Predicted Value	Residual	Standard Pred. v.	Standard Residual	Std.Err. Pred.Val	Mahalanobis Distance	Deleted Residual	Cook's Distance
1	1.743.211,000	1.707.824,750	35.386,250	1,290	0,925	29.475,387	3,858	87.013,813	1,023
2	1.629.915,000	1.675.301,250	-45.386,250	-0,089	-1,186	18.028,533	0,887	-58.334,871	0,172
3	1.645.295,000	1.678.190,250	-32.895,250	0,033	-0,860	16.201,390	0,545	-40.079,898	0,066
4	1.670.005,000	1.673.416,625	-3.411,625	-0,169	-0,089	14.481,759	0,257	-3.981,935	0,001
5	1.720.758,000	1.656.534,750	64.223,250	-0,885	1,678	17.526,234	0,789	81.272,000	0,315
6	1.637.371,000	1.641.140,500	-3.769,500	-1,538	-0,099	25.015,158	2,530	-6.582,523	0,004
7	1.653.919,000	1.669.035,375	-15.116,375	-0,355	-0,395	16.330,417	0,568	-18.482,494	0,014
8	1.679.765,000	1.676.823,875	2.941,125	-0,025	0,077	20.113,682	1,321	4.063,928	0,001
9	1.716.441,000	1.718.412,625	-1.971,625	1,739	-0,052	33.506,004	5,245	-8.450,658	0,012



Analiza višestruke regresije za  $y = f(x_2, x_3)$

N=9	Regression Summary for Dependent Variable: Y (Spreadsheet1) R= ,50450667 R2= ,25452698 Adjusted R2= ,00603597 F(2,6)=1,0243 p						
	b*	Std.Err. of b*	b	Std.Err. of b	t(6)	p-value	
	Intercept		883.378,190	626.609,021	1,410	0,208	
	x2	-0,663	0,843	-0,434	0,552	-0,786	0,462
	x3	1,024	0,843	0,000	0,000	1,215	0,270


Predicted & Residual Values Y									
	Observed Value	Predicted Value	Residual	Standard Pred. v.	Standard Residual	Std.Err. Pred.Val	Mahalanobis Distance	Deleted Residual	Cook's Distance
1	1.743.211,000	1.694.824,250	48.386,750	0,849	1,193	27.459,045	2,779	89.363,188	0,742
2	1.629.915,000	1.668.485,500	-38.570,500	-0,435	-0,951	17.400,240	0,584	-47.275,070	0,083
3	1.645.295,000	1.673.226,375	-27.931,375	-0,204	-0,689	16.048,291	0,364	-33.118,586	0,035
4	1.670.005,000	1.671.687,875	-1.682,875	-0,279	-0,042	15.201,551	0,235	-1.958,047	0,000
5	1.720.758,000	1.659.066,000	61.692,000	-0,894	1,521	18.674,117	0,808	78.296,570	0,264
6	1.637.371,000	1.651.069,625	-13.698,625	-1,284	-0,338	23.628,086	1,827	-20.740,318	0,030
7	1.653.919,000	1.688.194,125	-34.275,125	0,526	-0,845	16.701,840	0,468	-41.277,527	0,059
8	1.679.765,000	1.670.922,250	8.842,750	-0,316	0,218	30.540,945	3,649	20.433,551	0,048
9	1.716.441,000	1.719.204,125	-2.763,125	2,037	-0,068	35.622,324	5,285	-12.103,108	0,023



Analiza višestruke regresije za  $y = f(x_1, x_2, x_3)$

N=9	Regression Summary for Dependent Variable: Y (Spreadsheet1) R= ,58482095 R2= ,34201555 Adjusted R2= ----- F(3,5)=,86632 p					
	b*	Std.Err. of b*	b	Std.Err. of b	t(5)	p-value
Intercept			-1.481.472,242	2.971.181,151	-0,499	0,639
$x_1$	0,910	1,116	0,555	0,680	0,815	0,452
$x_2$	0,311	1,477	0,204	0,967	0,211	0,841
$x_3$	0,897	0,881	0,000	0,000	1,017	0,356

Predicted & Residual Values Y									
	Observed Value	Predicted Value	Residual	Standard Pred. v.	Standard Residual	Std.Err. Pred.Val	Mahalanobis Distance	Deleted Residual	Cook's Distance
1	1.743.211,000	1.707.416,375	35.794,625	1,262	0,858	32.204,275	3,875	88.486,547	0,669
2	1.629.915,000	1.676.444,000	-46.529,000	-0,041	-1,115	20.394,936	1,022	-61.128,063	0,128
3	1.645.295,000	1.678.666,250	-33.371,250	0,053	-0,800	17.812,840	0,569	-40.805,242	0,044
4	1.670.005,000	1.673.461,500	-3.456,500	-0,166	-0,083	15.795,305	0,257	-4.034,434	0,000
5	1.720.758,000	1.657.179,875	63.578,125	-0,850	1,523	19.357,359	0,832	81.006,242	0,203
6	1.637.371,000	1.640.961,375	-3.590,375	-1,532	-0,086	27.294,861	2,533	-6.274,261	0,002
7	1.653.919,000	1.662.449,000	-8.530,000	-0,629	-0,204	35.950,371	5,048	-33.071,352	0,117
8	1.679.765,000	1.682.427,250	-2.662,250	0,211	-0,064	34.453,387	4,564	-8.360,267	0,007
9	1.716.441,000	1.717.674,500	-1.233,500	1,693	-0,030	36.708,996	5,301	-5.451,252	0,003



### **Prilog 3: Proračuni koeficijenta varijacije regresije**

Proračuni koeficijenata varijacije regresije

	Model 1	Model 2	Model 3	Model 4	Model 5	Model 6	Model 7
Residual^2	5174140692	5497777609	4510935732	3010716900	1252186689	2341277576	1281255179
	1808598888	1537022224	1249189500	2383770770	2059911689	1487683470	2164947841
	802624313	661010528	568524414	1068464484	1082097473	780161709	1113640327
	22320900	4596736	109065	17970181	11639185	2832068	11947392
	2007577636	2268462105	3055657284	2710568985	4124625841	3805902864	4042177979
	1623676951	1337264334	657640380	431065835	14209130	187652327	12890793
	702760218	505013256	723112436	51346182	228504793	1174784194	72760900
	12749363	173840929	118018348	570708210	8650216	78194228	7087575
	853837620	306586968	34410	265795961	3887305	7634860	1521522
SUM	13008286582	12291574688	10883221570	10510407507	8785712321	9866123295	8708229507
ST.DEV.	43108	41904	39430	41854	38266	40551	41733
VARIANCE (%)	2,57	2,50	2,35	2,50	2,28	2,42	2,49



